

一种基于 EMD-BLS 的三相整流电路故障诊断方法

曾超俊¹, 王荣杰^{1,2}, 王亦春^{1,2}, 郜怀通¹, 林安辉^{1,2}, 韩冉¹

(1. 集美大学轮机工程学院, 福建 厦门 361021; 2. 福建省船舶与海洋工程重点实验室, 福建 厦门 361021)

[摘要] 针对三相整流电路的故障诊断, 提出了一种基于经验模式分解和宽度学习系统相结合的三相整流电路故障诊断方法。首先利用经验模式分解方法对故障信号进行分解, 提取基本模式分量的能量作为特征信号; 然后再利用时间复杂度、低分类高精度的宽度学习系统建立故障诊断的分类模型, 有效地完成三相整流电路的故障分类。实验结果表明, 经验模式分解特征提取效果显著, 宽度学习系统故障分类器具有较好的适应性, 较快的计算速度和较高的准确度。

[关键词] 三相整流电路; 故障诊断; 经验模态分解; 宽度学习系统

[中图分类号] TH 7

A Fault Diagnosis Method of Three-Phase Rectifier Based on Empirical Mode Decomposition and Broad Learning System

ZENG Chaojun¹, WANG Rongjie^{1,2}, WANG Yichun^{1,2}, GAO Huaitong¹, LIN Anhui^{1,2}, HAN Ran¹

(1. School of Marine Engineering, Jimei University, Xiamen 361021, China;

2. Fujian Provincial Key Laboratory of Naval Architecture and Ocean Engineering, Xiamen 361021, China)

Abstract: For the fault diagnosis of three-phase rectifier circuit, this paper proposes a fault diagnosis method of three-phase rectifier circuit based on the combination of empirical mode decomposition and broad learning system. The method first uses the empirical mode decomposition method to decompose the fault signal and extract the basic mode energy of the component as the characteristic signal, and then the broad learning system with low time complexity and high classification accuracy is used to establish classification model for fault diagnosis, which effectively accomplish the fault classification of the three-phase rectifier circuit. The experimental results show that the empirical mode decomposition feature extraction effect is significant, the broad learning system fault classifier has better adaptability, faster calculation speed and higher accuracy.

Keywords: three-phase rectifier; fault diagnosis; empirical mode decomposition; broad learning system

0 引言

三相整流电路在实际运行中, 开关器件通常会发生开路和短路两种常见故障。准确识别三相整流电路故障对于电力系统的安全运行和避免灾难性事故极其重要^[1-3]。三相整流电路故障诊断的关键有二: 一是提取反映整流电路状态的特征信息, 二是对特征信息进行分类实现故障诊断^[4]。

[收稿日期] 2020-12-31

[基金项目] 农业部渔业装备与工程技术重点实验室基金项目(2018001); 国家自然科学基金项目(51879118); 交通运输行业高层次人才培养项目(2019-014); 福建省自然科学基金项目(2020J01688, 2019JD01704); 福建省科技拥军项目(B19101)

[作者简介] 曾超俊(1995—), 男, 硕士生, 从事电力电子故障诊断研究。通信作者: 王亦春(1980—), 男, 讲师, 从事风力发电和电力电子故障诊断研究。E-mail: jmuwyc@163.com

目前故障特征提取方法主要有^[5-7]：小波变换 (wavelet transform, WT)、主成分分析 (principal component analysis, PCA)、奇异值分解 (singular value decomposition, SVD) 和经验模态分解 (empirical mode decomposition, EMD) 等。小波变换时频分析方法可处理时变的非平稳信号，但无法提取反映信号非线性信息，分解的信号容易产生虚假频率^[8]；主成分分析法提取特征完全无参数限制，但解释其自身含义总是具有一定的不确定模糊性，提取出来的特征不如原始样本完整，贡献率小的主成分可能是整体差异的重要信息；奇异值分解法能在特征提取时去除噪声，但是只适用于数值型，对非方阵数据分解出的数据具有高不确定性^[9]；而 EMD 突破了传统时频分析的局限，并且在非平稳信号上表现良好，与传统的时频分析方法相比，EMD 具有自适应性、正交性和完整性的典型特征。

应用于三相整流电路故障类型分类的方法主要有^[10-13]：反向传播神经网络 (backpropagation neural network, BP)、概率神经网络 (probabilistic neural network, PNN)、支持向量机 (support vector machines, SVM)、极限学习机 (extreme learning machine, ELM) 和宽度学习系统 (broad learning system, BLS) 等。反向传播网络因具有自学习能力被广泛推崇，但经常陷入局部最优和网络训练能力差且收敛速度慢等困境；概率神经网络虽然克服了反向传播网络训练差收敛慢的缺点，但计算复杂度高且样本要求也高^[14]；支持向量机在多分类问题上存在无法达到高精度分类的困难，且求解分类问题需要消耗大量的存储空间；极限学习机结构相对简单，但当调整极限学习机结构时，重新训练耗费时间相当长^[15]；而宽度学习系统结构简单，可以通过增加映射节点和增强节点数目来提高性能，是为各种应用的快速通用逼近而设计的。

因此，本文将揭示故障本质局部特征的经验模态分解和计算复杂度低的宽度学习系统相结合，应用于三相整流电路故障诊断中。

1 故障诊断方法的建立

1.1 经验模态分解

经验模态分解采用黄锬于 1998 年提出的自适应信号分析方法^[16]。EMD 可以逐步分解信号并产生一系列固有模式函数 (IMF) 和 1 个残差余项的和，每 1 个 IMF 的获取均依赖于信号的局部时间尺度，不利用任何其他信息。EMD 的分解可以归纳为以下 4 个步骤。

步骤 1：找出信号 $x(t)$ 中的所有局部极大值和极小值点，再分别用曲线把所有极大值点和所有极小值点连接起来，得到信号 $x(t)$ 的上包络线 $f_{\max}(t)$ 和下包络线 $f_{\min}(t)$ 。与此同时把上包络线和下包络线的平均值用 $m(t)$ 表示^[17]。

步骤 2：设 $x(t)$ 与 $m(t)$ 的差记为 $h_1(t)$ ，即

$$h_1(t) = x(t) - m(t). \quad (1)$$

理想条件下， $h_1(t)$ 是一个基本模式分量 (IMF)。但是，实际环境下信号是复杂多变的，得到的差 $h_1(t)$ 中可能仍然存在非对称波。因此将 $h_1(t)$ 当成新的 $x(t)$ ，重复步骤 1 和 2 的操作，直至 $h_1(t)$ 为一个基本模式分量，记为

$$c_1(t) = h_1(t). \quad (2)$$

步骤 3：分解获得第一个基本模式分量 $c_1(t)$ 后，用 $x(t)$ 减去 $c_1(t)$ 得到余下的信号 $x_1(t)$ ，则

$$x_1(t) = x(t) - c_1(t). \quad (3)$$

步骤 4：把 $x_1(t)$ 当做新的 $x(t)$ ，重复以上 3 个步骤，多次分解得到

$$\begin{cases} x_2(t) = x_1(t) - c_2(t), \\ x_3(t) = x_2(t) - c_3(t), \\ \vdots \\ x_n(t) = x_{n-1}(t) - c_n(t), \end{cases} \quad (4)$$

直至满足筛选过程的极限停止准则，这一般是通过限制 $h_{1(k-1)}(t)$ 和 $h_{1k}(t)$ 之间的标准差 δ 的大小来

确定:

$$\delta = \sum_{t=0}^T |h_{1(k-1)}(t) - h_{1k}(t)| / |h_{1k}^2(t)|。$$

(5)

其中: T 表示信号时间跨度; 标准差 δ 一般取 $0.2 \sim 0.3$ 。最后停止条件下残余的项 $x_n(t) = r_n(t)$, 就是原始信号分解后留下的残差。通过 EMD 分解, 整个信号 $x(t)$ 被分解成若干个基本模态分量 $c_i(t), i=1,2,\cdots,n$, 和一个残差余项 $r_n(t)$ 的和, 即

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t)。$$

(6)

1.2 宽度学习系统

BLS^[18-20]是由澳门大学陈俊龙教授团队于 2018 年提出的一种替代深度学习网络的方法。它是将映射特征用作随机矢量函数链接神经网络 (RVFLNN) 输入的想法进行设计的。BLS 可以用高效的方式对新加入的数据进行更新 (输入的增量学习)。BLS 通过建立特征节点和增强节点, 来执行大数据的特征提取和降维, 用于更新 RVFLNN 中的输出权重, 即新增加的输入数据和新添加的增强节点的输出权重, 以保持系统的有效性。

BLS 结构图如图 1 所示, 假设给出输入数据 X 和增强节点 $\delta_i(XW_{ei} + \beta_{ei})$, 则它们成为第 i 个映射特征 Z_i , 其中 W_{ei} 和 β_{ei} 是具有适当维数的随机权重。令 $Z^i = [Z_1, \cdots, Z_i]$, 这是所有前 i 组映射特性的串联。同样, 将第 j 组增强节点 $\xi_j(Z^i W_{hj} + \beta_{hj})$ 表示为 H_j , 所有前 j 组增强节点的连接表示为 $H_j = [H_1, \cdots, H_j]$ 。

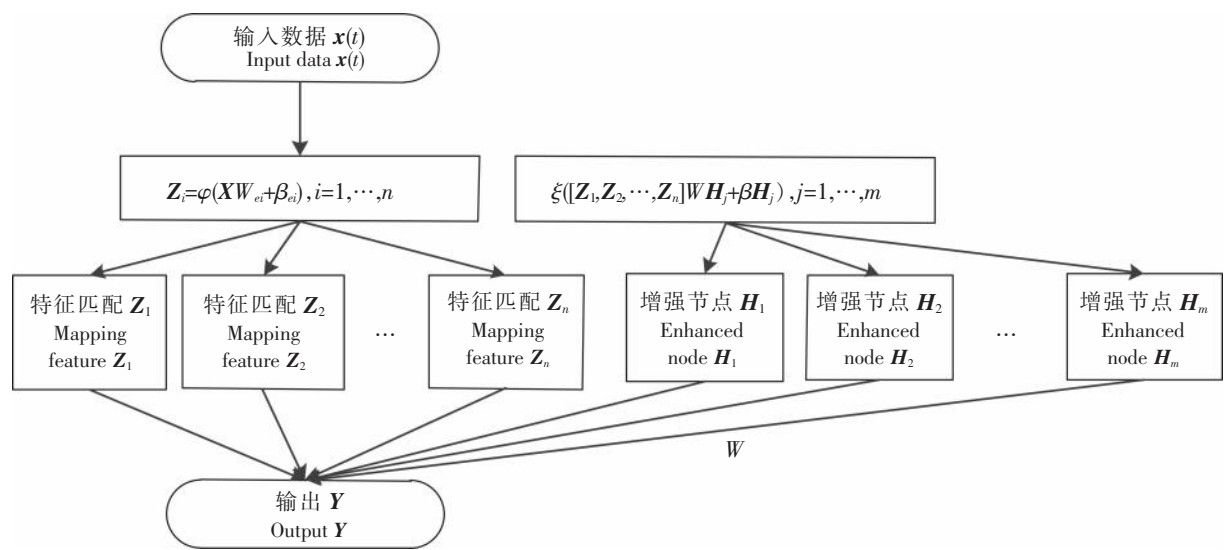


图 1 BLS 结构图
Fig.1 BLS structure diagram

在宽度学习系统中, 对初始 W_{ei} 进行微调以获取更好的特征。假设输入数据集 X 有 N 个样本, 每个样本有 M 个维度, Y 是输出矩阵且属于 $R^{N \times C[21]}$ 。对于 N 个特征映射, 每个映射生成 k 个节点, 可以表示为:

$$z_i = \varphi(XW_{ei} + \beta_{ei}), i = 1, \dots, n。$$

(7)

其中 W_{ei} 和 β_{ei} 是随机生成的。令所有特征节点 $Z_n \equiv [Z_1, \cdots, Z_n]$, 则第 m 组增强节点可表示为:

$$H_m \equiv \xi(Z_n W_{hm} + \beta_{hm})。$$

(8)

因此, BLS 可以表示为

$$Y = [Z_1, \dots, Z_n | \xi(Z_n W_{h1} + \beta_{h1}), \dots, \xi(Z_n W_{hm} + \beta_{hm})] W_m = [Z_n | H_m] W_m. \quad (9)$$

其中, W_m 代表输出层的权重。

对于一个输入系统 $x(k)$:

$$X(k) = [x_1, x_2, \dots, x_m]. \quad (10)$$

则它的增强节点

$$H = \xi(W_1 X + b_1), \quad (11)$$

它的宽度神经网络的输出

$$Y = W_2 \cdot [X | H]. \quad (12)$$

其中: m 代表不同的尺度长, 这是人为设定的常数; W 和 b 是随机输入权重; ξ 是增强节点函数。

1.3 三相整流电路故障分析

为了验证所提出的 EMD-BLS 故障诊断方法的有效性, 在 Simulink 仿真实验平台上模拟三相整流电路, 分析出现的故障, 仿真模型如图 2 所示。在整个运行过程中, 晶闸管故障表现极其明显。

本文对晶闸管故障进行研究, 将晶闸管开路和短路作为晶闸管故障, 以晶闸管不正常工作为基准, 把故障分成六大类:

- 1) 晶闸管无故障;
- 2) 只有一个晶闸管发生故障, 即 VT1、VT2、VT3、VT4、VT5 和 VT6 之中有一个发生故障;
- 3) 只有一个晶闸管发生短路故障, 即 VT1、VT2、VT3、VT4、VT5 和 VT6 之中有一个发生短路故障;
- 4) 同相不同组的两只晶闸管同时发生开路故障, 即 VT1 和 VT4、VT2 和 VT5、VT3 和 VT6 同时发生开路故障;
- 5) 同组不同相的两晶闸管同时发生故障, 即 VT1 和 VT3、VT1 和 VT5、VT3 和 VT5、VT2 和 VT4、VT4 和 VT6、VT6 和 VT2 同时故障;
- 6) 不同组不同相的两晶闸管同时发生开路故障, 即 VT1 和 VT2、VT2 和 VT3、VT5 和 VT6、VT1 和 VT6、VT3 和 VT4、VT5 和 VT4 同时故障。

共计 28 种故障。

1.4 故障诊断流程

基于 EMD-BLS 的三相整流电路故障诊断方法的流程图如图 3 所示。首先对三相整流电路开关器件信号进行 EMD 分解, 得到一系列基本模式分量 (IMF), 构成特征矩阵; 然后把所得特征提取值输入 BLS 模型, 对输入特征数据进行线性变换, 形成 BLS 的特征节点, 通过非线性变换使特征节点随机生成一个增强节点^[22]; 再将所有的映射特性和增强节点都直接连接到输出, 通过伪代码得到相应输出的权重, 在得到输出权重后, 进行训练并输出结果。

BLS 极大地缩短了计算时间, 而且可以通过快速的增量学习来扩展网络结构, 而无需进行全面完整的再次网络训练。




图 2 三相桥式整流电路
Fig.2 Three-phase bridge rectifier

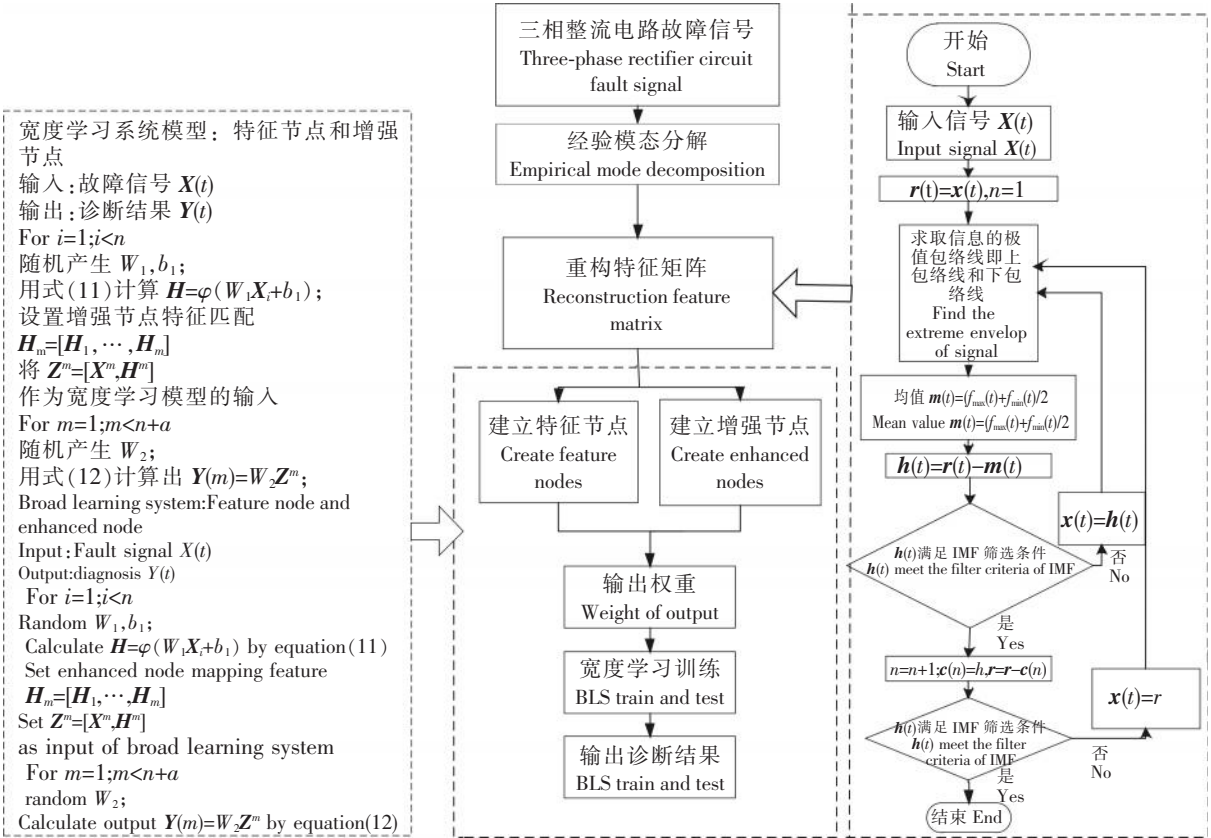


图3 EMD-BLS 故障诊断流程图
Fig.3 Flowchart of EMD-BLS based fault diagnosis

2 实验结果与分析

2.1 特征提取方法比较

为了验证基于 EMD 分解的特征提取效果, 将 EMD 与小波变换、主成分分析方法和奇异值分解法三种特征提取法得到的特征输入 BLS 进行训练测试比较。

2.1.1 小波变换

如式 (13), 将信号分解成一系列小波函数的叠加, 信号的局部特征用小波函数来逼近, 把基波函数 $\psi(t)$ 经过位移 τ 后, 在不同尺度 a 下的待分析的信号 $f(t)$ 做内积^[23], 有:

$$WT(a, \tau) = \int_{-\infty}^{\infty} f(t) \times \psi((t - \tau)/a) dt / \sqrt{a}.$$
 (13)

2.1.2 主成分分析

主成分分析方法主要分为四步: 1) 对所有特征求取数据均值 \bar{x} 和样本方差 S^2 ; 2) 求协方差矩阵 $Cov(X, Y)$; 3) 求协方差矩阵 C 的特征值 λ 和相对应的特征向量 u ; 4) 把原始特征投影到选取的特征向量上, 得到降维后的矩阵 y_i 。推导公式如下^[24]:

$$\bar{x} = \sum_{i=1}^N x_i / n,$$
 (14)

$$S^2 = \sum_{i=1}^N (x_i - \bar{x})^2 / (n - 1),$$
 (15)

$$Cov(X, Y) = E[(X - E(X))(Y - E(Y))] = \sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y}) / (n - 1),$$
 (16)

$$Cu = \lambda u,$$
 (17)

$$\begin{bmatrix} y_1^i \\ y_2^i \\ \vdots \\ y_k^i \end{bmatrix} = \begin{bmatrix} u_1^T \cdot (x_1^i, x_2^i, \dots, x_n^i)^T \\ u_2^T \cdot (x_1^i, x_2^i, \dots, x_n^i)^T \\ \vdots \\ u_k^T \cdot (x_1^i, x_2^i, \dots, x_n^i)^T \end{bmatrix}。$$

(18)

2.1.3 奇异值分解

奇异值分解如式 (19)^[25] 为

$$A = U \Sigma V'。$$

(19)

其中：矩阵 A 是一个 $m \times n$ 的矩阵； U 是一个 $m \times m$ 的矩阵； Σ 是一个 $m \times n$ 的矩阵，除了主对角线上的元素以外全为 0，主对角线上的每个元素都称为奇异值； V 是一个 $n \times n$ 的矩阵； U 和 V 都是酉矩阵，即满足 $U'U = I$ ， $V'V = I$ 。

将得到的特征矩阵输入到 BLS 网络中进行训练比较。BLS 的特征节点和增强节点都相同，经过 10 次实验得到 3 种不同触发角的实验结果（如表 1 所示），NONE 为未进行特征提取的原始数据。

由表 1 可看出，当触发角为 0° 、 30° 和 60° 时，与没有特征提取的原始数据进行比较，应用特征提取方法能有效地减少训练时间和提高准确度。 0° 和 30° 时 EMD 的特征提取效果明显，测试精度达到 100%，在这四种特征提取方法中的表现是最好的。当触发角为 30° 时，虽然利用 SVD 进行特征提取可以有效提高训练时间，但其测试精度为 92.86%，而 EMD 方法为 100%；同时，与 WT、PCA 提取的特征数据相比较，EMD 方法可以有效地减少训练时间和测试时间，提高特征提取的稳定性。当触发角为 60° 时，用 EMD 方法提取的训练时间和测试时间都要比 WT、PCA 和 SVD 少，而且在一定程度上还提高了测试精度。综上所述，EMD 方法能较好地去除数据之间的冗余，保持数据的有效性，相比其他方法对提高 BLS 模型的分类准确率更有效。

表 1 触发角为 0° 、 30° 、 60° 时不同特征提取方法的比较

Tab. 1 Comparison of different feature extraction methods when the trigger angle is 0° , 30° , 60°

解发角 Trigger angle	方法 Method	训练时间 Train time/s	训练精度 Test accuracy/%	测试时间 Test time/s	测试精度 Test accuracy/%
0°	未提取特征 NONE	1.939	100.00	0.761	92.86
	经验模态分解 EMD	1.664	96.43	0.542	100.00
	小波变换 WT	1.842	92.86	0.664	92.86
	主成分分析法 PCA	1.724	96.43	0.638	96.43
	奇异值分解 SVD	1.694	92.86	0.592	92.86
30°	未提取特征 NONE	2.121	100.00	0.857	96.43
	经验模态分解 EMD	1.716	100.00	0.575	100.00
	小波变换 WT	1.881	92.86	0.664	96.43
	主成分分析 PCA	1.986	85.71	0.661	92.86
	奇异值分解 SVD	1.672	92.86	0.531	92.86
60°	未提取特征 NONE	2.089	100.00	0.773	92.86
	经验模态分解 EMD	1.631	96.43	0.527	96.43
	小波变换 WT	1.879	92.86	0.704	92.86
	主成分分析 PCA	1.891	96.43	0.638	96.43
	奇异值分解 SVD	1.644	100.00	0.592	92.86

2.2 故障分类方法的比较

为了验证 EMD-BLS 故障诊断方法的有效性，把用 EMD 提取后的数据输入到不同的分类器中进行比较，即与 EMD-ELM、EMD-BP、EMD-PNN、EMD-SVM 共 4 种故障诊断方法进行比较。ELM、BP、SVM 的隐藏层选择 Sigmoid 函数，BLS 的增强层选择 Sigmoid 函数。同时，从间隔 $[-1, 1]$ 上的标

准均匀分布中提取 BLS 中特征节点层和增强节点层的权重和偏移量。此外，实验结果用每种方法得到的 10 次平均值描述。三种不同触发角的故障分类实验结果分别见表 2。

由表 2 可以看出：当触发角为 0°时，ELM 在训练和测试过程中表现出很好的准确性，训练准确率为 100%，测试准确率为 100%，但其训练时间和测试时间远远多于其他分类模型；BLS 模型的训练时间仅需 1.664 s，优于 ELM、BP、PNN、SVM 的训练时间。当触发角为 30°时，5 种分类方法都能获得较高的训练精度和测试精度，其中 BLS 的训练时间和测试时间分别只需要 1.716 s 和 0.575 s，分别低于 ELM、BP 和 PNN、SVM。当触发角为 60°时，SVM 方法可以更快地实现故障诊断，训练和测试最快，但是训练精度和测试精度比 BLS 更低；BLS 模型应用于故障分类，训练准确率和测试准确率均为 96.43%，分类精度优于其他分类模型。综上所述，三相整流电路经 EMD 分解特征提取后，用 BLS 分类与用 ELM、BP、PNN、SVM 分类相比，BLS 能够相对较快精准地完成分类，在不同的故障数据类型下可以以最好的测试精度实现故障诊断。

表 2 触发角为 0°、30°、60°时不同分类方法的比较

Tab. 2 Comparison of experimental results of different classification methods when the trigger angle is 0°, 30°, 60°

解发角 Trigger angle	方法 Method	训练时间 Train time/s	训练精度 Test accuracy/%	测试时间 Test time/s	测试精度 Test accuracy/%
0°	宽度学习系统 BLS	1.664	96.43	0.542	100.00
	神经网络 BP	2.621	75.00	0.896	78.57
	极限学习机 ELM	11.390	100.00	2.316	100.00
	概率神经网络 PNN	2.428	82.14	0.751	89.29
	机器学习机 SVM	2.354	92.85	0.649	96.43
30°	宽度学习系统 BLS	1.716	100.00	0.575	100.00
	神经网络 BP	2.912	96.43	0.842	96.43
	极限学习机 ELM	12.140	100.00	3.153	96.43
	概率神经网络 PNN	2.327	100.00	0.683	96.43
	机器学习机 SVM	2.149	100.00	0.597	96.43
60°	宽度学习系统 BLS	1.631	96.43	0.527	96.43
	神经网络 BP	2.541	96.43	0.731	85.71
	极限学习机 ELM	11.950	85.71	2.452	96.43
	概率神经网络 PNN	2.051	92.86	0.648	89.29
	极限学习机 SVM	1.584	89.29	0.439	92.86

3 结论

本文提出一种基于 EMD-BLS 的三相整流电路故障诊断方法，利用 EMD 方法提取特征，获得低维特征矩阵，再将提取后的数据输入 BLS 模型，实现故障诊断。经过 MATLAB 仿真实验，EMD 特征提取方法效果较好，BLS 分类迅速准确，EMD-BLS 方法能有效地实现故障诊断。

[参 考 文 献]

[1] 任磊, 韦微, 龚春英, 等. 电力电子电路功率器件故障特征参数提取技术综述 [J]. 中国电机工程学报, 2015, 35(12): 3089-3101.

[2] 周东华, 史建涛, 何潇. 动态系统间歇故障诊断技术综述 [J]. 自动化学报, 2014, 40(2): 161-171.

[3] CHENG H, CHEN W B, WANG Y, et al. Open circuit fault diagnosis and fault tolerance of three-phase bridgeless rectifier [J]. Electronics, 2018, 7(11): 291. DOI:10.3390/electronics7110291.

[4] 文成, 周传德. 基于改进 EMD 和形态滤波的滚动轴承故障诊断 [J]. 中国测试, 2016, 42(1): 121-125.

[5] 李微, 谭阳红, 彭永进. 基于小波分析及网络的电力电子电路故障诊断方法 [J]. 电机与控制学报, 2005(6): 37-44.

- [6] 唐勇波, 桂卫华, 彭涛, 等. PCA 和 KICA 特征提取的变压器故障诊断模型 [J]. 高电压技术, 2014, 40(2): 557-563.
- [7] XU L, CHATTERTON S, PENNACCHI P. Rolling element bearing diagnosis based on singular value decomposition and composite squared envelope spectrum [J]. Mechanical Systems and Signal Processing, 2021, 148: 107-117. DOI:10.1016/j.ymssp.2020.107174.
- [8] 陈争光, 周泽昕, 王兴国, 等. 基于双树复小波变换的混合直流输电线路行波保护方法 [J]. 电网技术, 2019, 43(10): 3832-3840.
- [9] YAO J H, JIANG X N, WANG S G, et al. SVM-BiLSTM: a fault detection method for the gas station iot system based on deep learning [J]. IEEE Access, 2020, 8: 203712-203723. DOI:10.1109/ACCESS.2020.3034939.
- [10] LI C L, XIONG J B, ZHU X T, et al. Fault diagnosis method based on encoding time series and convolutional neural network [J]. IEEE Access, 2020, 8: 165232-165246.
- [11] LIU X L, ZHANG X Y, LUAN Z Q, et al. Rolling bearing fault diagnosis based on EEMD sample entropy and PNN [J]. The Journal of Engineering, 2019, 2019(23): 31-36.
- [12] CHEGINI S N, BAGHERI A, NAJAFI F. A new intelligent fault diagnosis method for bearing in different speeds based on the FDAF-score algorithm, binary particle swarm optimization, and support vectormachine [J]. Soft Computing, 2020(24): 10005-10023. DOI:10.1007/S00500-019-04516-2.
- [13] WANG X B, YANG Z X, WONG P K, et al. Novel paralleled extreme learning machine networks for fault diagnosis of wind turbine drivetrain [J]. Memetic Computing, 2018, 11: 127-142. DOI:10.1007/S12293-018-0277-2.
- [14] LI M Y, WEI Q M, WANG H Y, et al. Research on fault diagnosis of time-domain vibration signal based on convolutional neural networks [J]. Systems Science & Control Engineering, 2019, 7(3): 73-81.
- [15] LI H T, BAI J C, CUI X, et al. A new secondary decomposition-ensemble approach with cuckoo search optimization for air cargo forecasting [J]. Applied Soft Computing Journal, 2020, 90: 1568-1577.
- [16] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis [J]. Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences, 1998, 454(1971): 903-995.
- [17] 胡芑庆, 陈徽鹏, 程哲, 等. 基于经验模态分解和深度卷积神经网络的行星齿轮箱故障诊断方法 [J]. 机械工程学报, 2019, 55(7): 9-18.
- [18] CHEN C L P, LIU Z L. Broad learning system: a new learning paradigm and system without going deep [C] //32nd Youth Academic Annual Conference of Chinese Association of Automation (YAC), Hefei: IEEE, 2017: 1271-1276.
- [19] CHEN C L P, LIU Z L. Broad learning system: an effective and efficient incremental learning system without the need for deep architecture [J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(1): 10-24.
- [20] CHEN C L P. Broad learning system and its structural variations [C] //IEEE 16th International Symposium on Intelligent Systems and Informatics (SISY). Subotica: IEEE, 2018: 000011-00012.
- [21] 刘长良, 武英杰, 甄成刚. 基于变分模态分解和模糊 C 均值聚类的滚动轴承故障诊断 [J]. 中国电机工程学报, 2015, 35(13): 3358-3365.
- [22] HAN R, WANG R J, ZENG G M. Identification of dynamical systems using a broad neural network and particle swarm optimization [J]. IEEE Access, 2020, 8: 132592-132602. DOI:10.1109/ACCESS.2020.3009982.
- [23] 李红延, 周云龙, 田峰, 等. 一种新的小波自适应阈值函数振动信号去噪算法 [J]. 仪器仪表学报, 2015, 36(10): 2200-2206.
- [24] 王健, 冯健, 韩志艳. 基于流形学习的局部保持 PCA 算法在故障检测中的应用 [J]. 控制与决策, 2013, 28(5): 683-687.
- [25] 古莹奎, 曾磊, 张敏, 等. 基于 CEEMDAN-SQI-SVD 的齿轮箱局部故障特征提取 [J]. 仪器仪表学报, 2019, 40(5): 78-88.

(责任编辑 朱雪莲 英文审校 黄振坤)